

機械学習と 数理モデル

順問題と逆問題のデータ駆動型解法

武石 直也 (東京大学)

2024-10-22

日本地震学会2024年度秋季大会

本講演の内容

- ① 機械学習で数理モデルの順問題を解く
- ② 機械学習で数理モデルの逆問題を解く
- ③ 機械学習と数理モデルのハイブリッドモデリング

※ 整理のための分類にすぎず、考え方や手法には共通する部分が多くあります

機械学習で数理モデルの順問題を解く

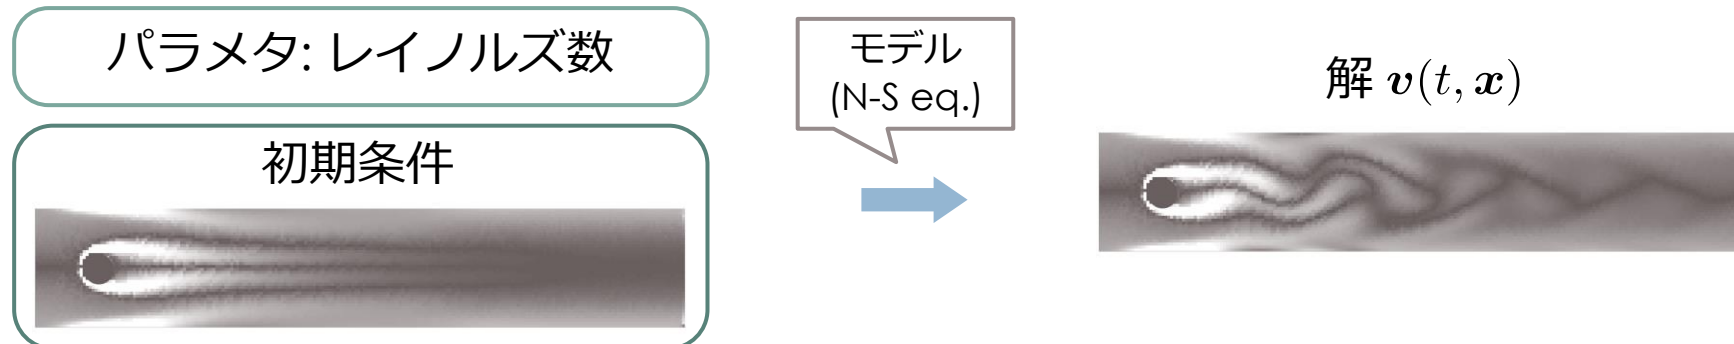
PINNs, DGM, neural operators

「順問題」とは

- 例えば、Navier–Stokes方程式：

$$\frac{\partial \mathbf{v}}{\partial t} + (\mathbf{v} \cdot \nabla) \mathbf{v} = \mathbf{g} - \frac{1}{\rho} \nabla p + \frac{\mu}{\rho} \nabla^2 \mathbf{v}$$

- この方程式を解くとは、↑を満たす未知量（関数） \mathbf{v} と p を求めること
- 数値的な解でもよい
- パラメタ、初期/境界条件を決めて、方程式を解くことを**順問題**と定義



微分方程式の深層学習による解法: PINN / DGM

- 偏微分方程式

$$\frac{\partial u(t, \mathbf{x})}{\partial t} - Lu(t, \mathbf{x}) = 0 \quad \text{for } t \in [0, T], \mathbf{x} \in \Omega$$




- 初期条件、境界条件

$$u(t_0, \mathbf{x}) = u_0(\mathbf{x}) \quad \text{for } \mathbf{x} \in \Omega$$

$$u(t, \mathbf{x}) = g(t, \mathbf{x}) \quad \text{for } t \in [0, T], \mathbf{x} \in \partial\Omega$$

- ニューラルネットワーク $u_\theta(t, \mathbf{x})$ で解 u を表す [Raissi+ 2019]

学習すべきパラメタ



$$\text{minimize}_\theta \sum_{t, \mathbf{x} \in [0, T] \times \Omega} \left\| \frac{\partial u_\theta(t, \mathbf{x})}{\partial t} - Lu_\theta(t, \mathbf{x}) \right\|^2 + \sum_{\mathbf{x} \in \Omega} \|u_\theta(t_0, \mathbf{x}) - u_0(\mathbf{x})\|^2 + \sum_{t, \mathbf{x} \in [0, T] \times \partial\Omega} \|u_\theta(t, \mathbf{x}) - g(t, \mathbf{x})\|^2$$

微分方程式の残差

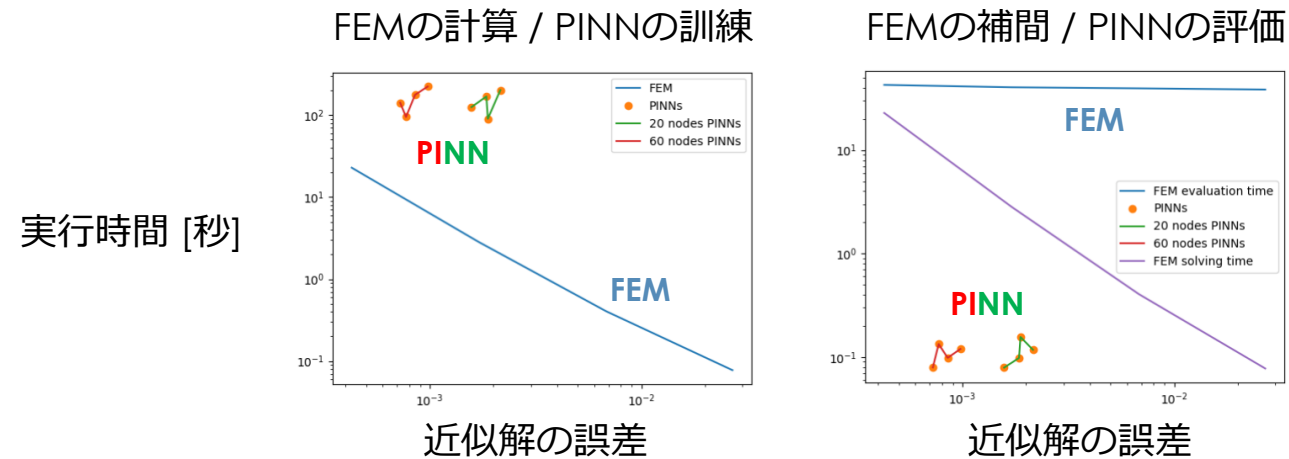
初期条件

境界条件

深層学習による微分方程式解法の利点

- メッシュフリーな表現
- 任意の点で観測データを使える
 - 微分方程式と観測データの両方にフィットさせる
- 数値解析より高速な場合もある
 - ホントか？ [Grossmann+ 2023]

(3次元ポアソン方程式の場合のみ、評価で有利)



figures from Grossmann+ (2023)

関連資料

- S. Wang, S. Sankaran, H. Wang, P. Perdikaris:
“[An Expert's Guide to Training Physics-informed Neural Networks](#)”,
arXiv:2308.08468

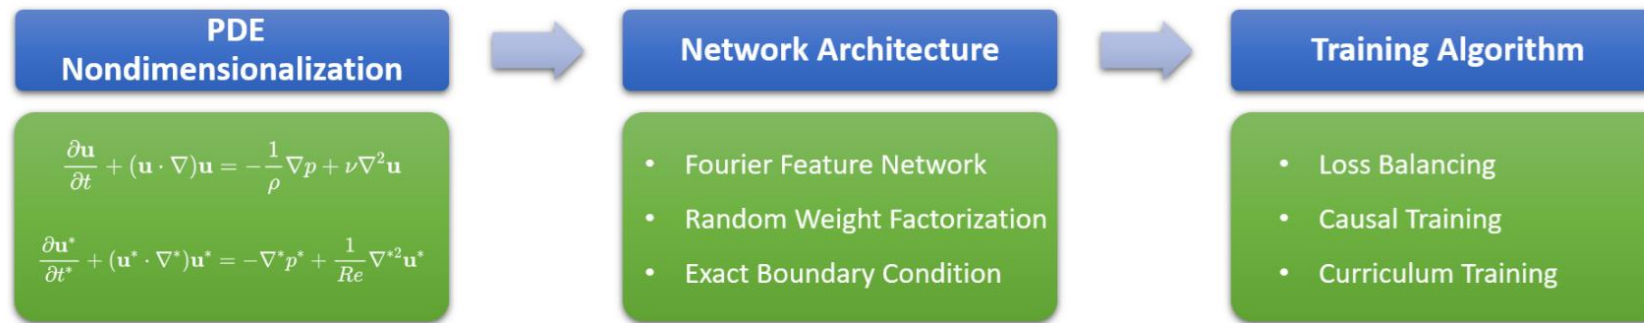


figure from Wang+ 2023

- PINNpapers
 - <https://github.com/idrl-lab/PINNpapers>
 - PINN関連論文のまとめ

関連キーワード

- Physics-informed neural networks (PINNs) [Raissi+ 2019]
- Deep Galerkin method (DGM) [Sirignano+ 2018]
 - PINN と concurrent work だと思われる
- Neural operators [Li+ 2021; Lu+ 2021; Kovachki+ 2023] (よく知られた手法だが、今回は割愛)
 - 特定の初期/境界条件での特殊解を学習するのではなく、
初期条件 \mapsto 時刻 t での解 のような、関数 \mapsto 関数の作用素をデータから学習する

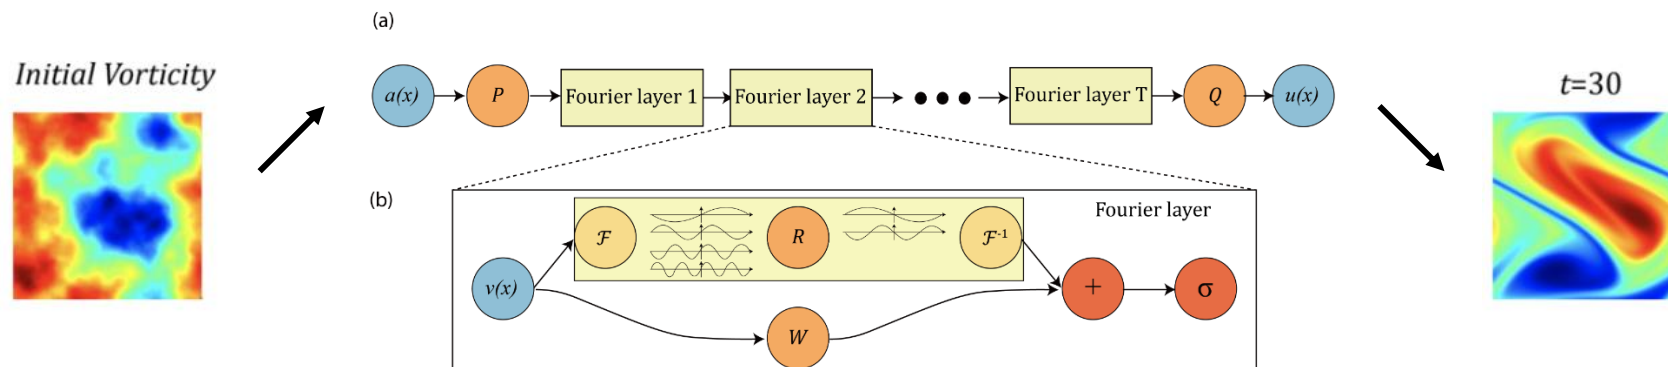


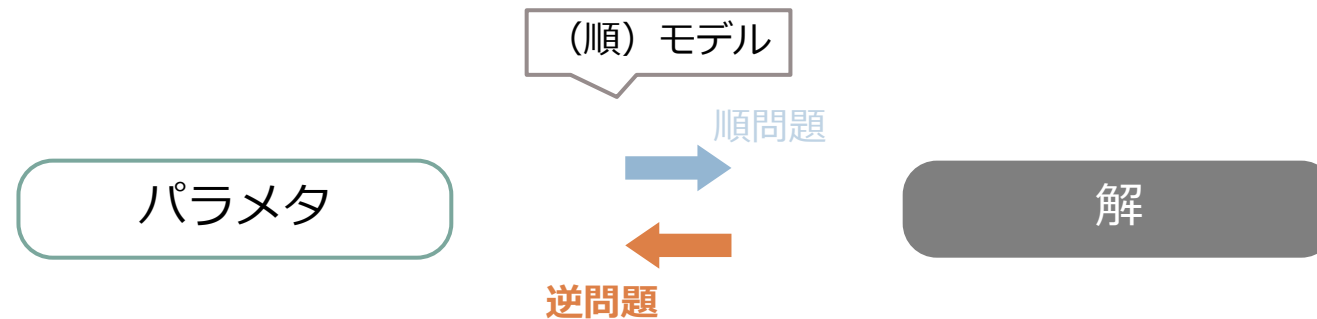

figure from Li+ (2021) with modification

機械学習で数理モデルの逆問題を解く

simulation-based inference


「逆問題」とは

- 例えば、逆運動学
 - 順モデル: $(\theta_0, \theta_1, \theta_2) \mapsto (x, y)$
 - 観測 $x_o := (x_o, y_o)$ が与えられたとき、それに対応するパラメタ $(\theta_0, \theta_1, \theta_2)$ の値を求める
 - 腕の長さ l_1, l_2 は順モデルの一部としてわかっているとす
- 観測（得るべき解）と順モデルを決めて、対応するパラメタを求めるのを**逆問題**と定義



劣決定な逆問題

- ある x を実現する $\theta := (\theta_1, \theta_2, \theta_3)$ がいくつもある (無数に) ある



- 正則化 何らかの規準 $g(\theta)$ を設定して、「好ましい」 θ を選択
- **ベイズ推論** 事前分布 $p(\theta)$ を設定して、事後分布 $p(\theta | x)$ を推論

ベイズ的逆問題

■ ベイズの定理

パラメタ事後分布
(ほしいもの)

$$p(\boldsymbol{\theta} | \boldsymbol{x}) = \frac{p(\boldsymbol{x} | \boldsymbol{\theta})p(\boldsymbol{\theta})}{p(\boldsymbol{x})}$$

Headache 2.

順モデルで決まる
観測の分布 (尤度)

パラメタ事前分布
(所与とする)

$$= \int p(\boldsymbol{x} | \boldsymbol{\theta})p(\boldsymbol{\theta})d\boldsymbol{\theta}$$

Headache 1.

観測の周辺分布

■ 周辺分布 $p(\boldsymbol{x})$ の計算はだいたい難しい

- 変分推論 (variational inference) による近似
- マルコフ連鎖モンテカルロ (MCMC) 法によるサンプリング




} 尤度 $p(\boldsymbol{x} | \boldsymbol{\theta})$
の計算が必要

■ 尤度 $p(\boldsymbol{x} | \boldsymbol{\theta})$ は順モデルとしてあるはずでは? → そうでもない

Simulation-based inference


- 尤度関数 $p(x | \theta)$ の値を計算せず、事後分布 $p(\theta | x)$ を推論する問題
 - 「尤度なし推論 (likelihood-free inference)」 または「シミュレーションに基づく推論 (simulation-based inference; **SBI**)」
 - 同じことを指すはずだが、最近の深層学習ベースの方法では SBI と呼ぶ傾向

通常の
推論問題



SBI

x_1, \dots, x_N



Approximate Bayesian computation (ABC)


- 観測 x_0 が与えられたとき、事後分布 $p(\theta \mid x = x_0)$ (からのサンプル) を得たい
 - 事前分布 $p(\theta)$ (から θ を生成する機械) ; および
 - シミュレータ: $p(x \mid \theta)$ から x を生成する機械 をもっている
- ABC rejection

Input 事前分布, シミュレータ, 観測 x_0 , 閾値 ϵ , 統計量 S

Output 保存したサンプルの集合 $\{\theta\}$

- 1 $i = 1, \dots, N$ について、
- 2 事前分布とシミュレータから (θ_i, x_i) を生成
- 3 $\|S(x_i) - S(x_0)\| < \epsilon$ なら θ_i を保存

x を比較するための
特徴量抽出器



- 十分統計量 S と閾値 ϵ をいい感じに決めなくてははいけない
- 観測 x_0 が入ってくるたびにシミュレータを多数回実行する必要がある

深層学習によるSBI: 発想

- 発想は簡単

シミュレータから
データを生成して
深層生成モデルを学習する



深層学習によるSBI: 事後分布を直接学習 (NPE)

- 観測 x_o が与えられたとき、事後分布 $p(\boldsymbol{\theta} \mid \boldsymbol{x} = \boldsymbol{x}_o)$ (からのサンプル) を得たい
- Neural posterior estimation (NPE)

Input 事前分布, シミュレータ

Output ニューラルネットによる事後分布の近似 $q_\phi(\boldsymbol{\theta} \mid \boldsymbol{x})$

- 1 $i = 1, \dots, N$ について、
- 2 事前分布とシミュレータから、 $(\boldsymbol{\theta}_i, \boldsymbol{x}_i)$ を生成して保存
- 3 保存した $\{(\boldsymbol{\theta}, \boldsymbol{x})\}$ から、事後分布 $q_\phi(\boldsymbol{\theta} \mid \boldsymbol{x})$ (normalizing flowsなど) を学習

基本的には
一度だけ実行




Input 観測 x_o , 近似した事後分布 $q_\phi(\boldsymbol{\theta} \mid \boldsymbol{x})$

Output 事後分布の評価値 $q(\boldsymbol{\theta} \mid \boldsymbol{x} = \boldsymbol{x}_o)$

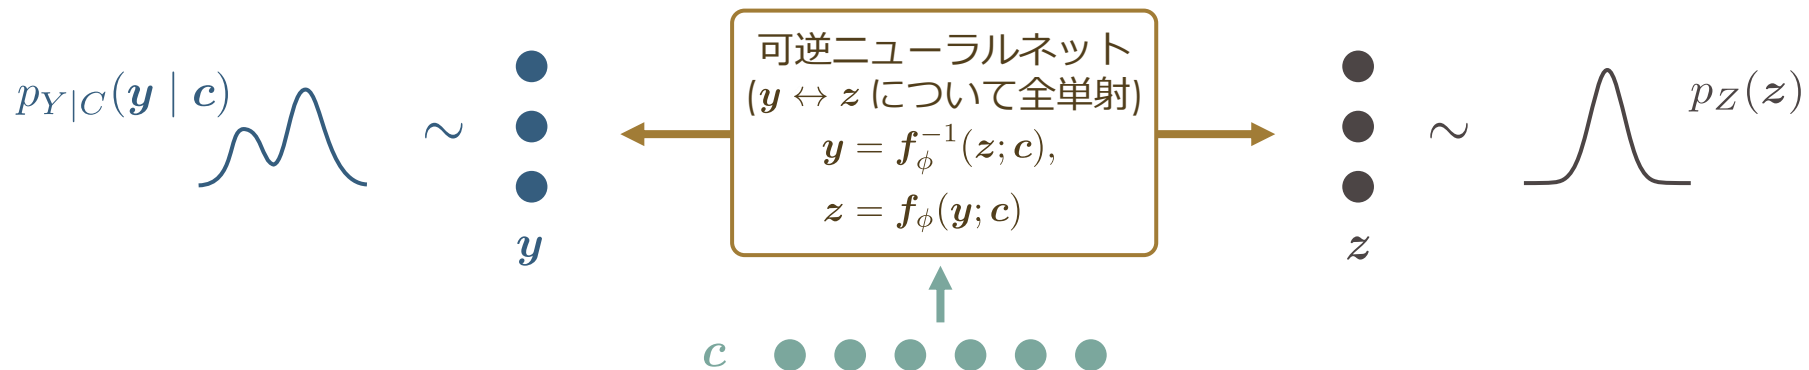
- 1 $q(\boldsymbol{\theta} \mid \boldsymbol{x} = \boldsymbol{x}_o)$ を計算

条件付き分布を normalizing flows で学習する

- Normalizing flows: $p_Y(\mathbf{y}) = p_Z(\mathbf{f}_\phi(\mathbf{y})) \left| \frac{\partial \mathbf{f}_\phi(\mathbf{y})}{\partial \mathbf{y}} \right|$



- Conditional normalizing flows: $p_{Y|C}(\mathbf{y} | \mathbf{c}) = p_Z(\mathbf{f}_\phi(\mathbf{y}; \mathbf{c})) \left| \frac{\partial \mathbf{f}_\phi(\mathbf{y}; \mathbf{c})}{\partial \mathbf{y}} \right|$



深層学習によるSBIの利点

- Normalizing flows などにより、複雑な事後分布を直接表現できる
 - 最近では flow matching による continuous NF による柔軟なモデル [Wildberger+ 2023]
- シミュレーションの実行は、基本的には*データ生成時のみに起こる
 - 新たな観測に対する事後分布推論は、NNの実行だけ
 - *一部の方法では、新たな観測に対してデータ生成とモデル訓練が新たに発生
- ちなみに: PINNも逆問題に使える
 - 実際、多くの研究でPINNによる「逆問題」が扱われている
 - PINNに未知パラメタも入力して、同時に推定 または 後から最適化
 - PINNを微分可能なサロゲートとしている ... neural likelihood estimation と同様

SBI-based ANT

- Ambient noise tomographyなどをSBIで高速化
- UniGE, HES-SO（スイス）とIGG（イタリア）によるプロジェクト

Fonds national suisse Portail de données ☰

MIGRATE - A Multidisciplinary and InteGRated Approach for geoThermal Exploration

Matteo Lupi, Alexandros Kalousis, Domenico Montanari
01.11.2022 – 31.10.2026

Aperçu

Numéro de projet
209434

Instrument d'encouragement
Sinergia

Mise au concours
Sinergia 2021 Dezember

Montant accordé
2 315 136 CHF

Statut
En cours

Institution de recherche
Université de Genève - GE

SBIの結果の信頼性

- SBIによる分布は、最頻値周りに過剰に集中した状態 (overconfident) であることが多い [Hermans+ 2022]
 - 実験的な結果による報告
- false discovery の危険性



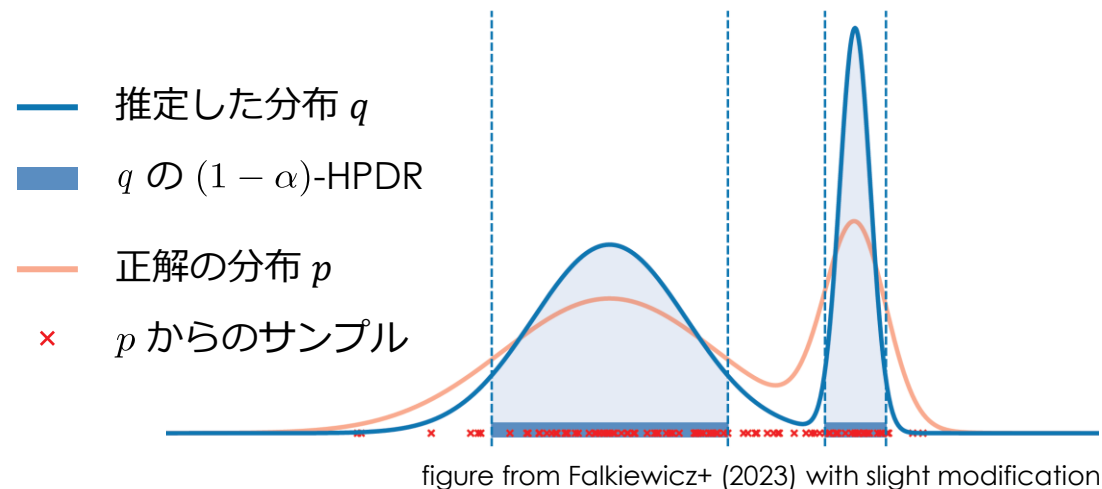



figure from Hermans+ (2022)


Overconfidence のはかり方

- 推定した分布が、どの程度 overconfident (または underconfident = conservative) なのかを定量化したい
 - 最高事後密度領域 (highest posterior density region; HPDR) による定義
 - “推定した分布 q が overconfident”
 - ⇔ “正解の分布 p からのサンプルが q の $(1 - \alpha)$ -HPDR に入る割合 $< 1 - \alpha$ ”
- $0 \leq 1 - \alpha \leq 1$ でグラフを描いて、対角線からの符号付き面積をはかる





ベンチマークの名称



色 = 訓練や推論に使ったデータのサイズ

figure from Hermans+ (2022)

Overconfidence のふせぎ方

- 問題を指摘した論文 [Hermans+ 2022] では、アンサンブリングを提案
- NREで学習する二値分類器のキャリブレーション [Delaunoy+ 2022]
- Coverageを微分可能な形で計算して、直接正則化 [Falkiewicz+ 2023]
 - coverageは微分可能ソートで計算できる

Algorithm 1 Computing the regularizer loss with calibration objective.

Require: Data batch $\{(\theta_i, x_i)\}_{i=1}^N$, model $\hat{p}(\theta|x)$, number of samples L , proposal distribution $I(\theta)$

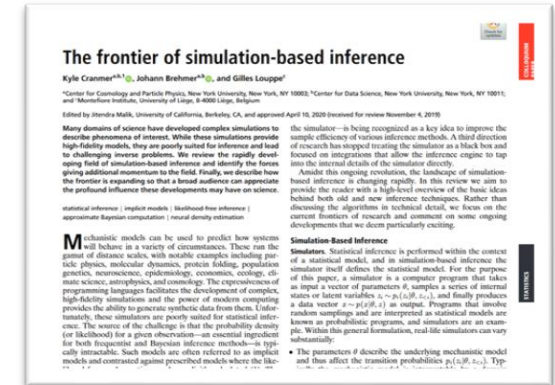
Ensure: Regularizer's loss R

```
1: for  $i \leftarrow 1$  to  $N$  do
2:    $p_i \leftarrow \hat{p}(\theta_i|x_i)$ 
3:   for  $j \leftarrow 1$  to  $L$  do
4:      $\theta_i^j \sim I(\theta)$  ▷ sampling from proposal distribution
5:      $p_i^j \leftarrow \hat{p}(\theta_i^j|x_i)$ 
6:   end for
7:    $\hat{\alpha}_{\text{HPDR}}^{L,IS}(\hat{p}, \theta_i, x_i) \leftarrow \frac{\sum_{j=1}^L p_i^j / I(\theta_i^j) \mathbb{1}[p_i^j < p_i]}{\sum_{j=1}^L p_i^j / I(\theta_i^j)}$  ▷ eq. (11)
8: end for
9:  $(\alpha_i | i = 1, \dots, N) \leftarrow \text{sort}(\{\hat{\alpha}_{\text{HPDR}}^{L,IS}(\hat{p}, \theta_i, x_i) | i = 1, \dots, N\})$ 
10:  $R \leftarrow \frac{1}{N} \sum_i (i/N - \alpha_i)^2$  ▷ the second term in eq. (12)
```

figure from Falkiewicz+ (2023)

関連資料

- K. Cranmer, J. Brehmer, G. Louppe: [“The Frontier of Simulation-Based Inference,”](#) PNAS **117**(48):30055-30062, 2020
- sbi [Tejero-Cantero+ 2020]
 - <https://sbi-dev.github.io/sbi/>
 - PyTorch と nflows をベースにしたSBIのライブラリ
- Awesome Neural SBI
 - <https://github.com/smsharma/awesome-neural-sbi>
 - 手法と応用の論文まとめ
- Simulation-based inference
 - <https://simulation-based-inference.org/>



SBI関連の論文は年々増加




figure from <https://simulation-based-inference.org/>
retrieved on 2024-05-24



機械学習と数理モデルの ハイブリッドモデリング

ハイブリッド（グレーボックス）モデリング

■ 機械学習モデル

(ニューラルネット, 決定木, カーネル法, ...)

- 大量のパラメタをもつことがある
- 同質かつ多量のデータが必要
- 実際のデータに適応できる
- 解釈しにくい


■ 科学モデル

(微分方程式, 数値計算, グラフ, 論理式, ...)

- 少数のパラメタで表現される (べき)
- 多様な少量のデータの蓄積
- 抽象化・理想化のために
実際のデータと合わないことがある
- 理解に貢献

■ 両者の「良いところ取り」ができないか？

- 予測をよりよく
- 解釈しやすく
- 融合の程度は様々
 - ・ 「物理で出てくる構造っぽいを使う」から
「**具体的な微分方程式を使う**」まで



Hamiltonian neural networks [Greydanus+ 2019]

- ハミルトニアンをニューラルネットで構成

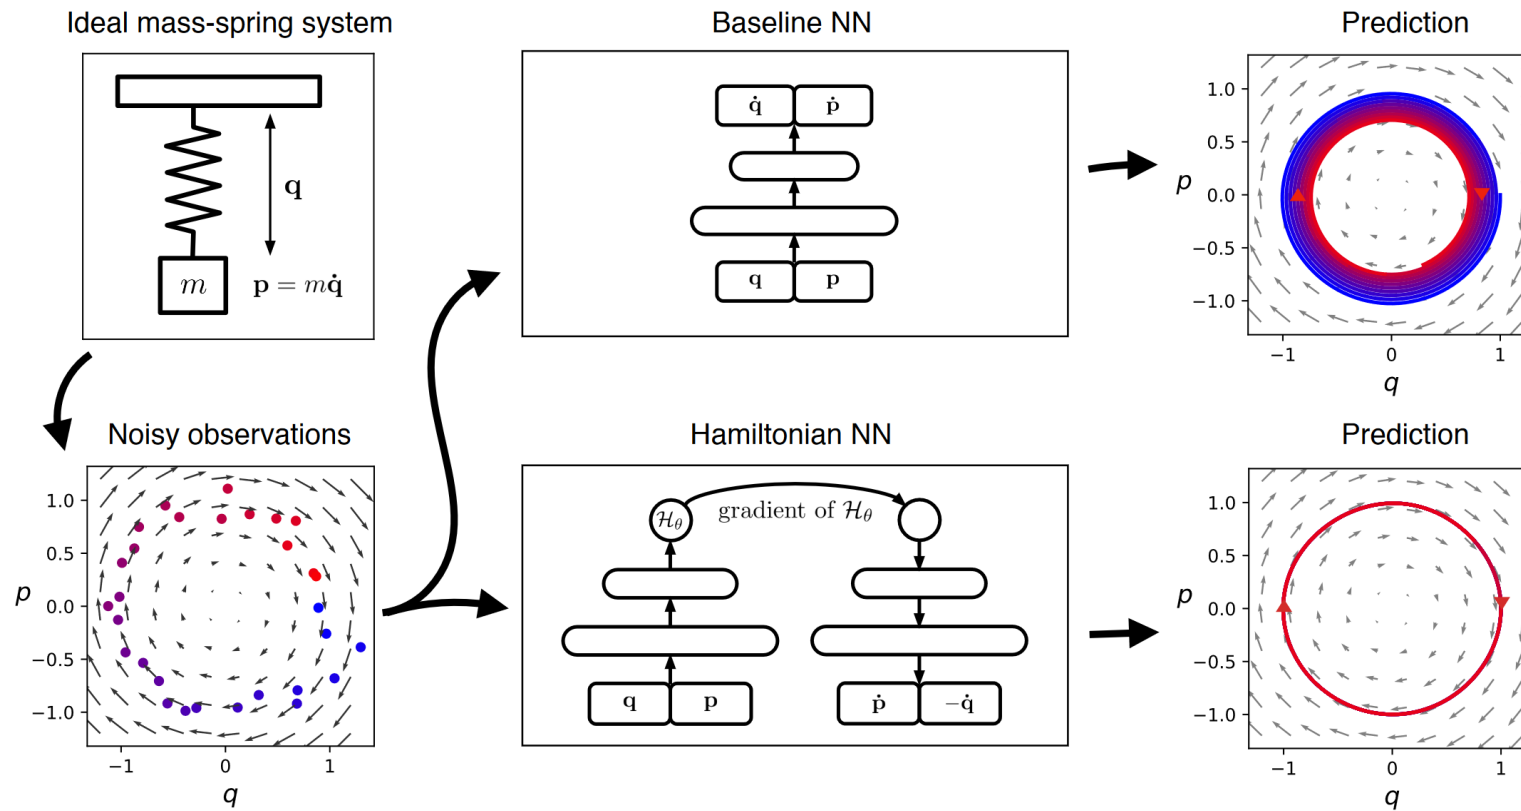


figure from Greydanus+ (2019)

COVID-19 感染者数予測 [Arik+ 2020]

- SIRモデルの係数を移動者数などの統計データから予測

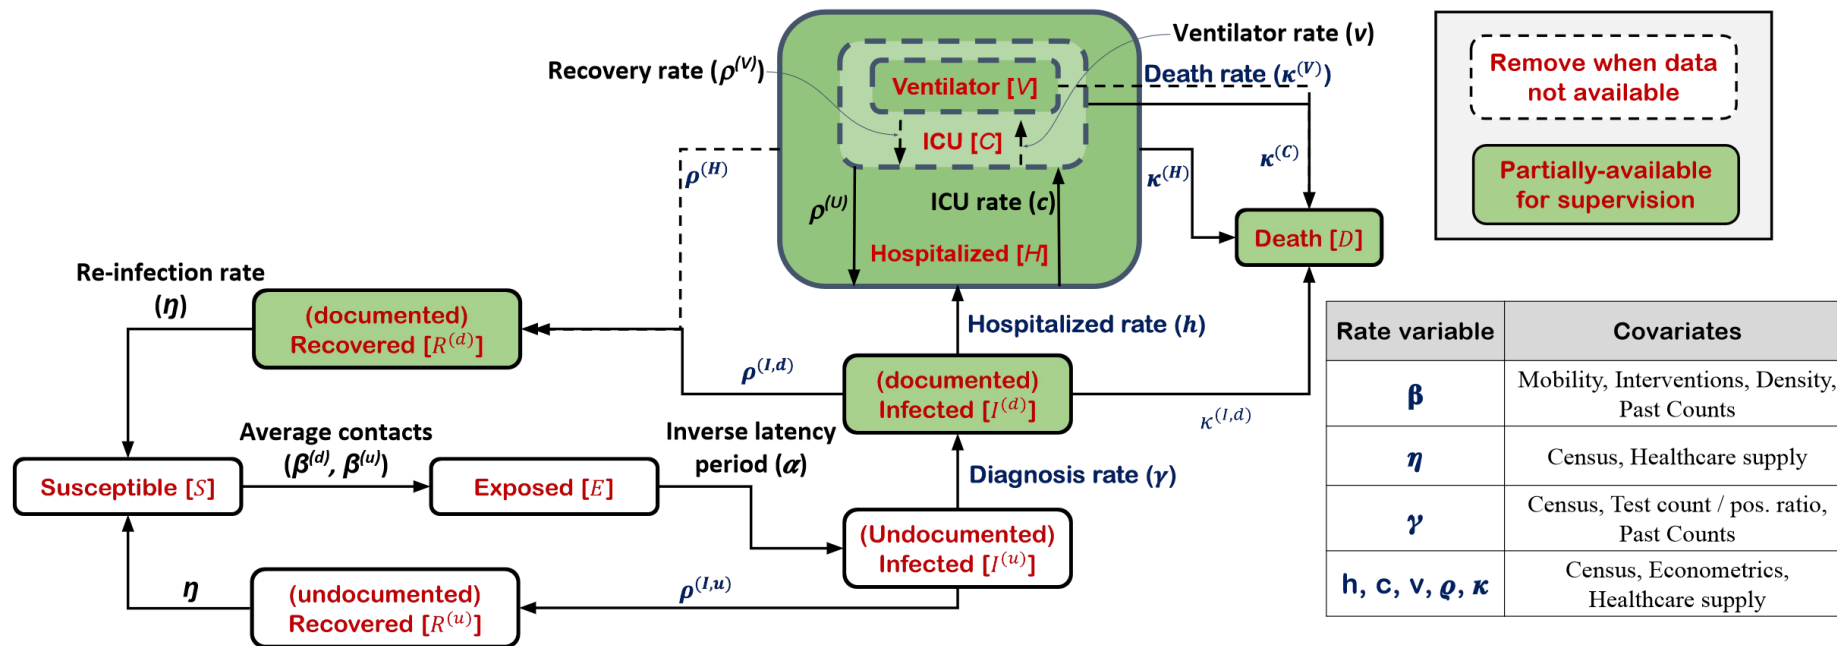


figure from Arik+ (2020)

渋滞長予測 [Shirakami+ 2023]

- 交通工学に基づくモデルの入力をGNNで予測

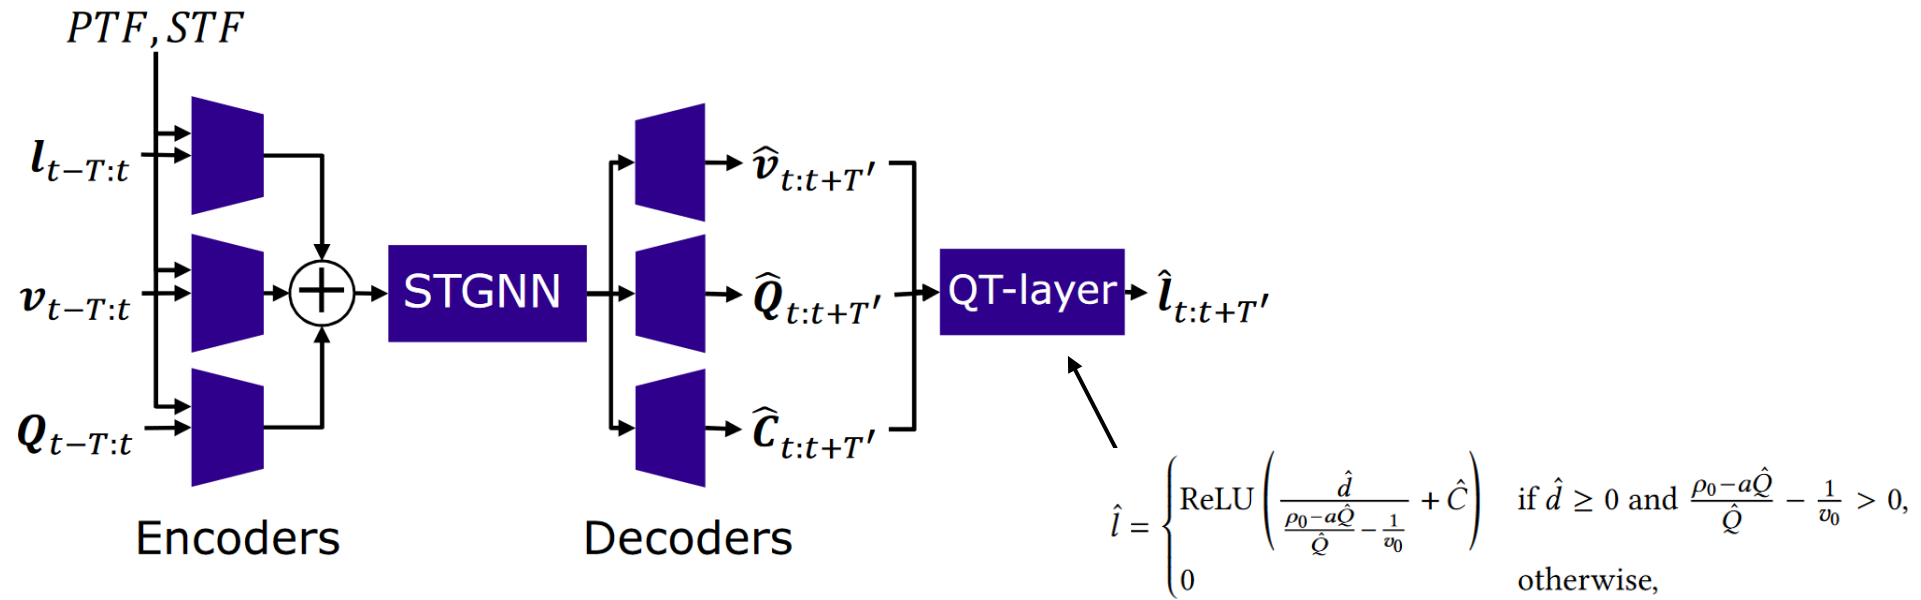


figure from Shirakami+ (2023)

気象予測 [Verma+ 2024]

- 予測値が移流方程式に従うようにする

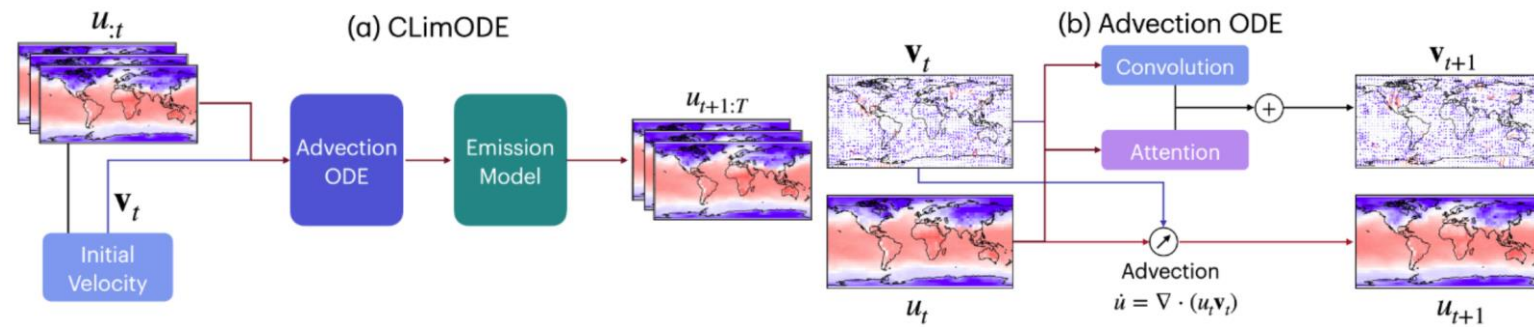
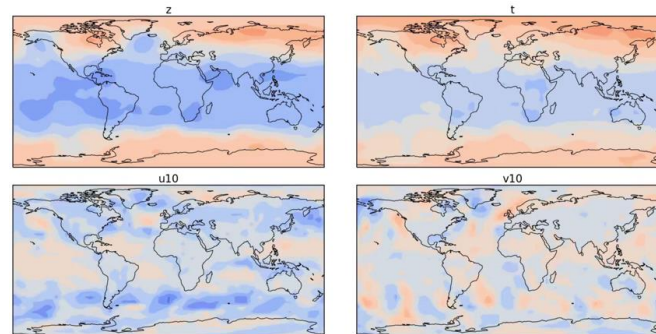


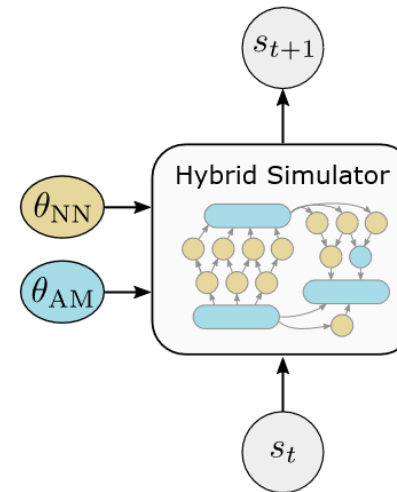

figure from Verma+ (2024)



video from the project page of Verma+ (2024)
<https://yogeshverma1998.github.io/ClimODE/>

接触などのある剛体シミュレーション

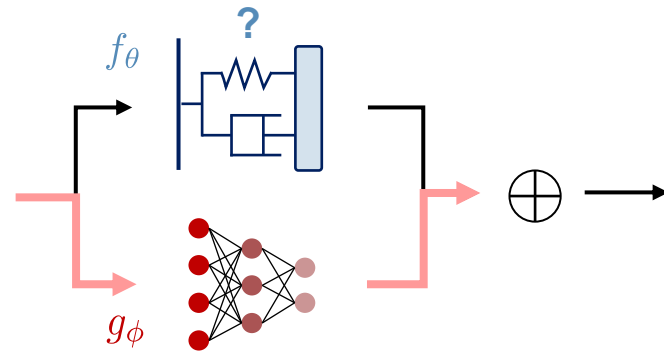
- ロボットなどのシミュレーションでは、接触判定、摩擦力、空気力などの精緻な再現が難しい
 - 難しい部分は機械学習でデータから獲得
[Ajay+ 2018; Hwangbo+ 2019; Zeng+ 2019; Golemo+ 2018; Heiden+ 2021]



figures from Heiden+ (2021)

科学モデルの未知パラメータ推定

- 機械学習モデルが「外」にあるとき、科学モデルの未知パラメータがうまく推定できない可能性
 - 機械学習モデルだけでデータにフィットできてしまう




- 例えば、 $y = f_\theta(x) + g_\phi(x)$
 - $g_\phi(x)$ が $y - f_\theta(x)$ にフィットして、 θ はなんでも良い、となってしまう
 - $g_\phi(x)$ の過剰な表現力を抑えるべき

制約 / 正則化によるハイブリッドモデル学習 1/2

- 加法的ハイブリッドモデルの学習 [Yin+ 2021]

- 特に、ハイブリッドな neural ODE:

$$\frac{dx}{dt} = f_{\theta}(x) + g_{\phi}(x) \quad \dots (*)$$



- 機械学習モデル g_{ϕ} のノルムがなるべく小さくなるように学習

$$\underset{\theta, \phi}{\text{minimize}} \quad \|g_{\phi}\| \quad \text{s.t.} \quad \forall \mathbf{X} \in \mathcal{D}, \mathbf{X} = \text{ODESolve}(*)$$

訓練データ (pointing to \mathcal{D})


訓練データ中のエピソード (pointing to $\forall \mathbf{X} \in \mathcal{D}$)

初期値問題ソルバ (初期値は所与としたり、推定したり) (pointing to $\text{ODESolve}(*)$)


- 拡張ラグランジュ法で解く
- 関数ノルムで「表現力」をあらわすという考え方；自然だが、本当にそれだけか？

制約 / 正則化によるハイブリッドモデル学習 2/2

- より一般の結合方法を想定 [Takeishi & Kalousis 2021]
 - 特に、デコーダ部分がハイブリッドな変分オートエンコーダ



- ハイブリッドモデルと「科学モデルだけの場合」の差を小さくなるよう正則化

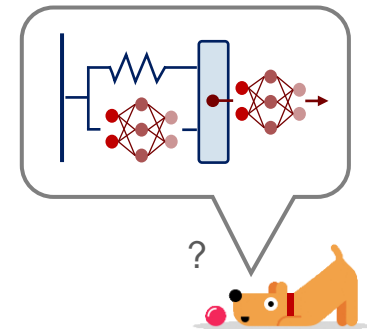


分布間の非類似度

NNを簡素なモデルで置き換える
(例えば $h(z) = 0, h(z) = Az + b$)

ハイブリッドモデリングのこれから

- まだ「始まった」ばかり
 - 自然な発想で古くから広く活用されているが、深層学習時代での探索はこれから
 - 定量的議論や厳密な計算が難しかった分野での応用
- 技術？
 - 学習の制約・正則化 ... 現状では限られたモデル構造しか扱えない
 - 科学モデルの「微分」
 - ハイブリッドモデルの自動構築
 - 残された機械学習モデルの（部分的）解釈
- 考え方？
 - 機械学習を含むモデルは、どのように科学的理解に資するか？



まとめ

機械学習と科学研究で用いられる**数理モデル**の関わりについて、主に**手法の観点から**考え方と最近の話題を紹介

- ① 機械学習で数理モデルの**順問題**を解く
 - PINNs, deep Galerkin ... 微分方程式による損失関数
- ② 機械学習で数理モデルの**逆問題**を解く
 - simulation-based inference ... シミュレータから生成したデータで深層生成モデル
- ③ 機械学習と数理モデルの**ハイブリッドモデリング**
 - 組み合わせ方や学習方法に注意が必要

- A. Ajay et al., “Augmenting Physical Simulators with Stochastic Neural Networks: Case Study of Planar Pushing and Bouncing,” in *Proceedings of the 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3066–3073, 2018.
- S. Ö. Arık et al., “Interpretable Sequence Learning for COVID-19 Forecasting,” in *Advances in Neural Information Processing Systems* 33, pp. 18807–18818, 2020.
- P. Berens, K. Cranmer, N. D. Lawrence, U. von Luxburg, and J. Montgomery, “AI for Science: An Emerging Agenda,” arXiv:2303.04217, 2023.
- D. M. Blei, “Build, Compute, Critique, Repeat: Data Analysis with Latent Variable Models,” *Annual Review of Statistics and Its Application*, vol. 1, no. 1, pp. 203–232, 2014.
- G. E. P. Box, “Science and Statistics,” *Journal of the American Statistical Association*, vol. 71, no. 356, pp. 791–799, 1976.
- J. Brehmer, S. Mishra-Sharma, J. Hermans, G. Louppe, and K. Cranmer, “Mining for Dark Matter Substructure: Inferring Subhalo Population Properties from Strong Lenses with Machine Learning,” *The Astrophysical Journal*, vol. 886, no. 1, p. 49, 2019.
- J. Brehmer, G. Louppe, J. Pavez, and K. Cranmer, “Mining Gold from Implicit Models to Improve Likelihood-Free Inference,” *Proceedings of the National Academy of Sciences*, vol. 117, no. 10, pp. 5242–5249, 2020.
- Y. Claes, V. A. Huynh-Thu, and P. Geurts, “Knowledge-Guided Additive Modeling for Supervised Regression,” in *Discovery Science*, Lecture Notes in Computer Science, vol. 14276, pp. 64–78, 2023.
- K. Cranmer, J. Pavez, and G. Louppe, “Approximating Likelihood Ratios with Calibrated Discriminative Classifiers,” arXiv:1506.02169, 2015.
- K. Cranmer, J. Brehmer, and G. Louppe, “The Frontier of Simulation-Based Inference,” *Proceedings of the National Academy of Sciences*, vol. 117, no. 48, pp. 30055–30062, 2020.
- E. de Bézenac, A. Pajot, and P. Gallinari, “Deep Learning for Physical Processes: Incorporating Prior Scientific Knowledge,” *Journal of Statistical Mechanics: Theory and Experiment*, vol. 2019, no. 12, 124009, 2019.
- A. Delaunoy, J. Hermans, F. Rozet, A. Wehenkel, and G. Louppe, “Towards Reliable Simulation-Based Inference with Balanced Neural Ratio Estimation,” in *Advances in Neural Information Processing* 35, pp. 20025–20037, 2022.
- C. Durkan, I. Murray, and G. Papamakarios, “On Contrastive Learning for Likelihood-Free Inference,” in *Proceedings of the 37th International Conference on Machine Learning*, pp. 2771–2781, 2020.
- M. Falkiewicz et al., “Calibrating Neural Simulation-Based Inference with Differentiable Coverage Probability,” in *Advances in Neural Information Processing* 36, pp. 1082–1099, 2023.

- F. Golemo, A. A. Taiga, A. Courville, and P.-Y. Oudeyer, "Sim-to-Real Transfer with Neural-Augmented Robot Simulation," in *Proceedings of the 2nd Conference on Robot Learning*, pp. 817–828, 2018.
- D. S. Greenberg, M. Nonnenmacher, and J. H. Macke, "Automatic Posterior Transformation for Likelihood-Free Inference," in *Proceedings of the 36th International Conference on Machine Learning*, pp. 2404–2414, 2019.
- S. Greydanus, M. Dzamba, and J. Yosinski, "Hamiltonian Neural Networks," in *Advances in Neural Information Processing Systems 32*, pp. 15379–15389, 2019.
- T. G. Grossmann, U. J. Komorowska, J. Latz, and C.-B. Schönlieb, "Can Physics-Informed Neural Networks Beat the Finite Element Method?" arXiv:2302.04107, 2023.
- Z. Hao et al., "Physics-Informed Machine Learning: A Survey on Problems, Methods and Applications," arXiv:2211.08064, 2022.
- E. Heiden, D. Millard, E. Coumans, Y. Sheng, and G. S. Sukhatme, "NeuralSim: Augmenting Differentiable Simulators with Neural Networks," in *Proceedings of the 2021 IEEE International Conference on Robotics and Automation*, pp. 9474–9481, 2021.
- J. Hermans, V. Begy, and G. Louppe, "Likelihood-Free MCMC with Amortized Approximate Ratio Estimators," in *Proceedings of the 37th International Conference on Machine Learning*, pp. 4239–4248, 2020.
- J. Hermans, A. Delaunoy, F. Rozet, A. Wehenkel, V. Begy, and G. Louppe, "A Trust Crisis in Simulation-Based Inference? Your Posterior Approximations Can Be Unfaithful," *Transactions on Machine Learning Research*, 2022.
- J. Hwangbo et al., "Learning Agile and Dynamic Motor Skills for Legged Robots," *Science Robotics*, vol. 4, no. 26, eaau5872, 2019.
- K. Kaheman, E. Kaiser, B. Strom, J. N. Kutz, and S. L. Brunton, "Learning Discrepancy Models from Experimental Data," arXiv:1909.08574, 2019.
- G. E. Karniadakis, I. G. Kevrekidis, L. Lu, P. Perdikaris, S. Wang, and L. Yang, "Physics-Informed Machine Learning," *Nature Reviews Physics*, vol. 3, pp. 422–440, 2021.
- C.-Y. Lai, P. Hassanzadeh, A. Sheshadri, M. Sonnewald, R. Ferrari, and V. Balaji, "Machine Learning for Climate Physics and Simulations," arXiv:2404.13227, 2024.
- Z. Li et al., "Fourier Neural Operator for Parametric Partial Differential Equations," in *Proceedings of the 9th International Conference on Learning Representations*, 2021.

- L. Lu, X. Meng, Z. Mao, and G. E. Karniadakis, "DeepXDE: A Deep Learning Library for Solving Differential Equations," *SIAM Review*, vol. 63, no. 1, pp. 208–228, 2021.
- L. Lu, P. Jin, G. Pang, Z. Zhang, and G. E. Karniadakis, "Learning Nonlinear Operators via DeepONet Based on the Universal Approximation Theorem of Operators," *Nature Machine Intelligence*, vol. 3, pp. 218–229, 2021.
- B. K. Miller, C. Weniger, and P. Forré, "Contrastive Neural Ratio Estimation," in *Advances in Neural Information Processing Systems 35*, pp. 3262–3278, 2022.
- D. Nganyu Tanyu et al., "Deep Learning Methods for Partial Differential Equations and Related Parameter Identification Problems," *Inverse Problems*, vol. 39, no. 10, 103001, 2023.
- G. Papamakarios and I. Murray, "Fast ϵ -Free Inference of Simulation Models with Bayesian Conditional Density Estimation," in *Advances in Neural Information Processing Systems 29*, pp. 1036–1044, 2016.
- G. Papamakarios, I. Murray, and T. Pavlakou, "Masked Autoregressive Flow for Density Estimation," in *Advances in Neural Information Processing Systems 30*, pp. 2335–2344, 2017.
- G. Papamakarios, E. Nalisnick, D. J. Rezende, S. Mohamed, and B. Lakshminarayanan, "Normalizing Flows for Probabilistic Modeling and Inference," *Journal of Machine Learning Research*, vol. 22, no. 57, pp. 1–64, 2021.
- G. Papamakarios, D. C. Sterratt, and I. Murray, "Sequential Neural Likelihood: Fast Likelihood-Free Inference with Autoregressive Flows," in *Proceedings of the 22nd International Conference on Artificial Intelligence and Statistics*, pp. 837–848, 2019.
- M. Raissi, P. Perdikaris, and G. E. Karniadakis, "Physics-Informed Neural Networks: A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations," *Journal of Computational Physics*, vol. 378, pp. 686–707, 2019.
- R. Ramakrishnan, P. O. Dral, M. Rupp, and O. A. von Lilienfeld, "Big Data Meets Quantum Chemistry Approximations: The Δ -machine Learning Approach," *Journal of Chemical Theory and Computation*, vol. 11, no. 5, pp. 2087–2096, 2015.
- M. Reichstein et al., "Deep Learning and Process Understanding for Data-Driven Earth System Science," *Nature*, vol. 566, no. 7743, pp. 195–204, 2019.
- T. Salzmann, E. Kaufmann, J. Arrizabalaga, M. Pavone, D. Scaramuzza, and M. Ryll, "Real-Time Neural MPC: Deep Learning Model Predictive Control for Quadrotors and Agile Robotic Platforms," *IEEE Robotics and Automation Letters*, vol. 8, no. 4, pp. 2397–2404, 2023.

- R. Shirakami, T. Kitahara, K. Takeuchi, and H. Kashima, "QTNNet: Theory-based Queue Length Prediction for Urban Traffic," in *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, pp. 4832–4841, 2023.
- J. Sirignano and K. Spiliopoulos, "DGM: A Deep Learning Algorithm for Solving Partial Differential Equations," *Journal of Computational Physics*, vol. 375, pp. 1339–1364, 2018.
- N. Takeishi and A. Kalousis, "Deep Grey-Box Modeling with Adaptive Data-Driven Models toward Trustworthy Estimation of Theory-Driven Models," in *Proceedings of the 26th International Conference on Artificial Intelligence and Statistics*, pp. 4089–4100, 2023.
- N. Takeishi and A. Kalousis, "Physics-Integrated Variational Autoencoders for Robust and Interpretable Generative Modeling," in *Advances in Neural Information Processing Systems 34*, pp. 14809–14821, 2021.
- A. Tejero-Cantero et al., "sbi: A Toolkit for Simulation-Based Inference," *Journal of Open Source Software*, vol. 5, no. 52:2505, 2020.
- Y. Verma, M. Heinonen, and V. Garg, "ClimODE: Climate and Weather Forecasting with Physics-Informed Neural ODEs," in *Proceedings of the 12th International Conference on Learning Representations*, 2024.
- L. von Rueden et al., "Informed Machine Learning – A Taxonomy and Survey of Integrating Knowledge into Learning Systems," *IEEE Transactions on Knowledge and Data Engineering*, vol. 35, no. 1, pp. 614–633, 2023.
- S. Wang, S. Sankaran, H. Wang, and P. Perdikaris, "An Expert's Guide to Training Physics-Informed Neural Networks," arXiv:2308.08468, 2023.
- A. Wehenkel et al., "Addressing Misspecification in Simulation-Based Inference through Data-Driven Calibration," arXiv:2405.08719, 2024.
- J. Willard, X. Jia, S. Xu, M. Steinbach, and V. Kumar, "Integrating Scientific Knowledge with Machine Learning for Engineering and Environmental Systems," *ACM Computing Surveys*, vol. 55, no. 4, p. 66:1–66:37, 2022.
- C. Winkler, D. Worrall, E. Hoogetboom, and M. Welling, "Learning Likelihoods with Conditional Normalizing Flows," arXiv:1912.00042, 2019.
- Y. Yin et al., "Augmenting Physical Models with Deep Networks for Complex Dynamics Forecasting," in *Proceedings of the 9th International Conference on Learning Representations*, 2021.
- A. Zeng, S. Song, J. Lee, A. Rodriguez, and T. Funkhouser, "TossingBot: Learning to Throw Arbitrary Objects with Residual Physics," in *Robotics: Science and Systems XV*, 2019.